

Best of breed httpd, forrest, solr and droids

Thorsten Scherler

Sociedad Andaluza para el Desarrollo
de la Sociedad de la Información S.A.U. (SADESI)

thorsten@apache.org

ApacheCon EU 2009, Amsterdam, 26 March 2009

ApacheCon



Leading the Wave
of Open Source



Sociedad Andaluza para el Desarrollo de la Sociedad de la Información S.A.U.
CONSEJERÍA DE INNOVACIÓN, CIENCIA Y EMPRESA



agenda

- use case – official gazette of the Junta de Andalucía
- architecture – the big picture
- forrest – generate static page
- solr – enable search
- droids – task automation
- httpd – answer high traffic requests
- next steps

A
pache
n
on



Leading the Wave
of Open Source

Mapa del sitio | Listas de correo | Buscar | BUSCAR



SERVICIOS

PORTADA | TEMAS | LA JUNTA | SERVICIOS | CONOCE ANDALUCÍA

Estás en: Portada » Servicios » BOJA » 2008 » Boletín 201

BOJA

- Último boletín
- Boletines por fecha
- Buscador del BOJA
- Preguntas frecuentes
- Otros boletines

Atención: La información contenida en estas páginas no es necesariamente exhaustiva, completa, exacta o actualizada. Únicamente los textos publicados en la edición impresa del Boletín Oficial de la Junta de Andalucía tienen carácter auténtico y validez oficial.

PDF Descargar boletín nº 201 completo

Boletín Oficial de la Junta de Andalucía

Boletín número 201 de 08/10/2008

1. DISPOSICIONES GENERALES

CONSEJERÍA DE GOBERNACIÓN

Acuerdo de 23 de septiembre de 2008, del Consejo de Gobierno, por el que se aprueba el Plan Estratégico de Defensa y Protección de las Personas Consumidoras y Usuarias de Andalucía 2008-2011.

Descargar en PDF

CONSEJERÍA PARA LA IGUALDAD Y BIENESTAR SOCIAL

Resolución de 25 de septiembre de 2008, del Instituto Andaluz de la Mujer, por la que se convoca la concesión de prestaciones económicas a mujeres víctimas de violencia, acogidas a Programas de Formación Profesional Ocupacional a desarrollar en los ejercicios 2008/2009.

Descargar en PDF

Sección siguiente >

ACCESIBILIDAD | LEGAL | CONTACTO

W3C WAI-AA WLAQ 1.0

Secciones

- 1. Disposiciones generales
- 2.1. Nombramientos, situaciones e incidencias
- 2.2. Oposiciones y concursos
- 3. Otras disposiciones
- 4. Administración de Justicia
- 5.1. Subastas y concursos de obras, suministros y servicios públicos
- 5.2. Otros anuncios



Sociedad Andaluza para el Desarrollo de la Sociedad de la Información S.A.U.
CONSEJERÍA DE INNOVACIÓN, CIENCIA Y EMPRESA



use case

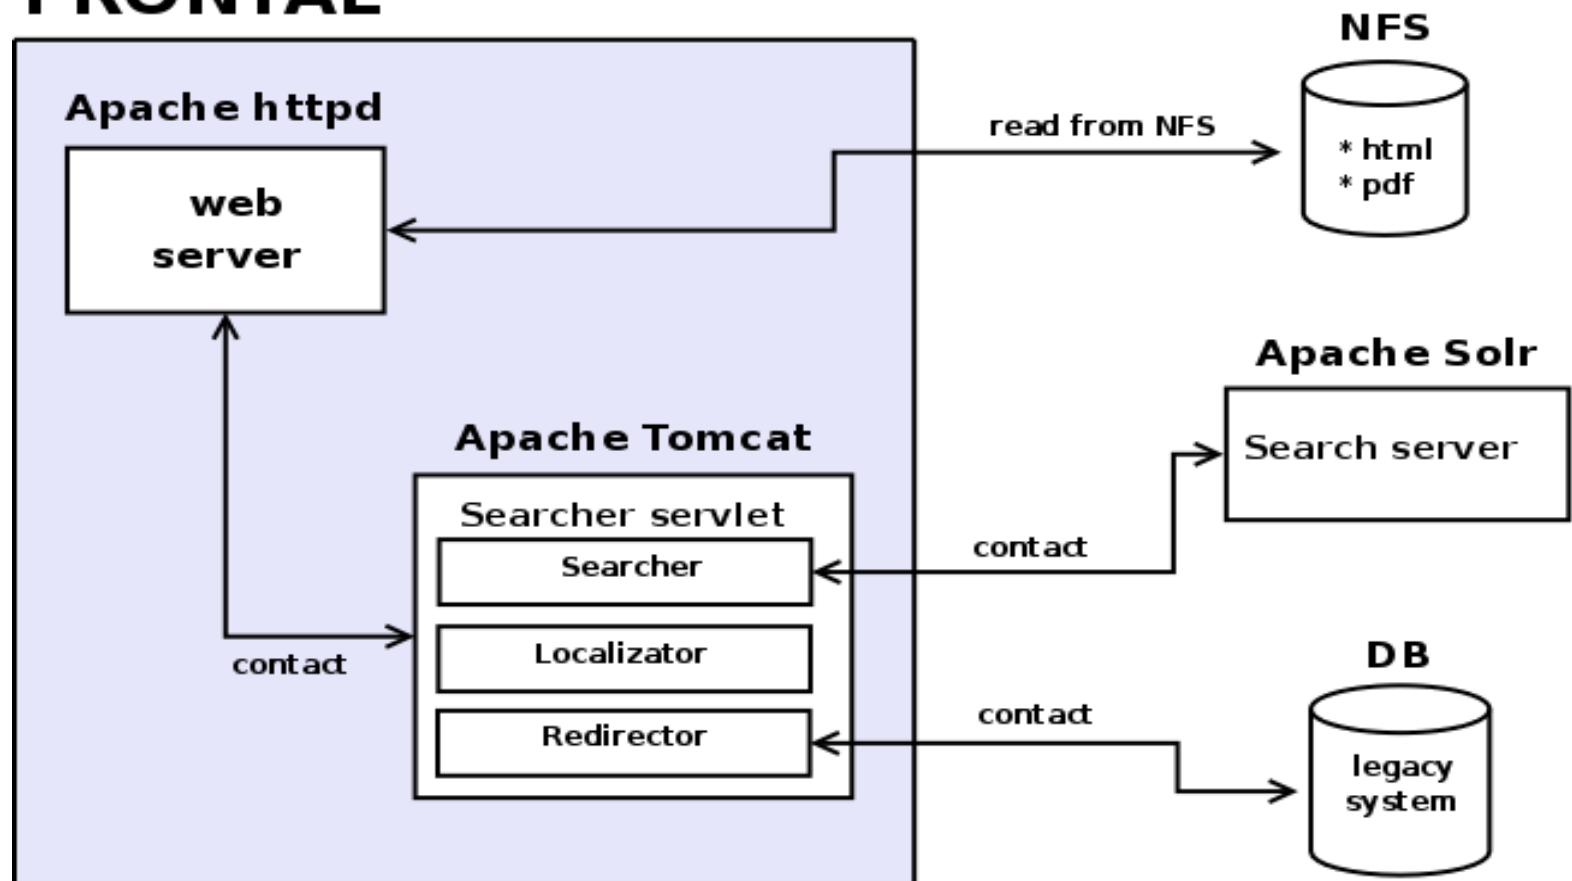
- <http://www.juntadeandalucia.es/boja>
- high traffic site
- high quantity of static content
- statistic 2008-08
 - site views: 1.5 million (60%)
 - pages (2.66/view): 4 million (60%)
 - requests: 22 million (35%)
 - upload: 300 GB (72%)



use case

- <http://www.juntadeandalucia.es>
- portal statistic 2008-08
 - site views: 2 million
 - pages (3.22/view): 6.7 million
 - requests: 62 million
 - upload: 420 GB

FRONTAL

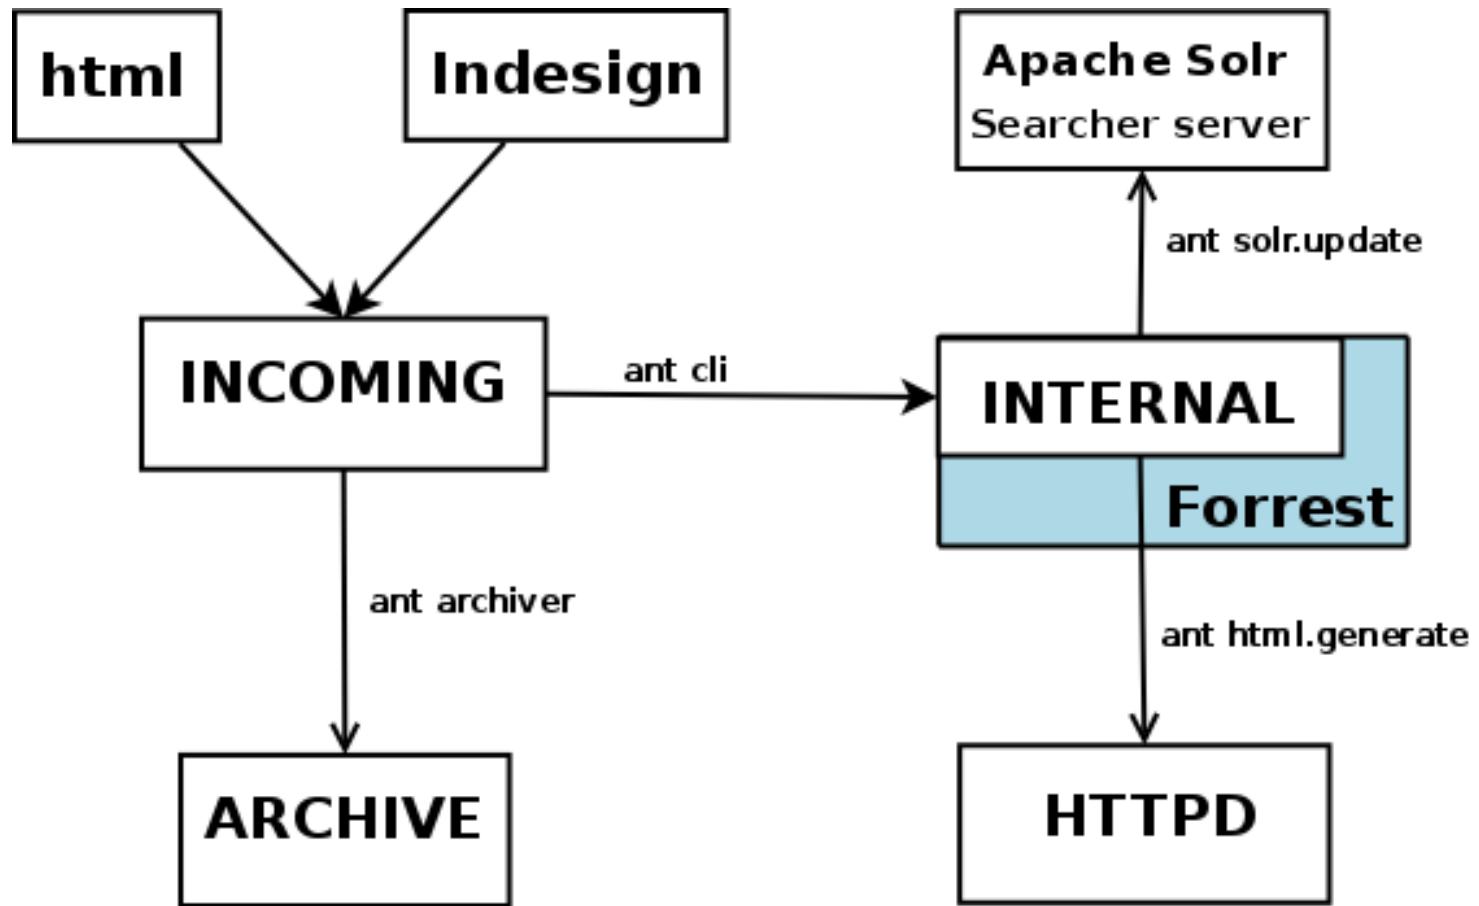




back-end

- daily updates of latest official gazette
 - input formats (pdf, xml & html)
 - html pages (gazette + global)
 - various pdf generation (fascicle, ...)
 - indexing of content (per disposition)

back-end architecture



forrest

Apache Forrest is a publishing framework that transforms input from various sources into a unified presentation in one or more output formats.

Forrest can generate static documents, or be used as a dynamic server, or be deployed by its automated facility.

forrest

- automated facility for page generation

```
<!-- macro for calling forrest site (with urifile)-->
<macrodef name="site-set">
  <attribute name="uri" />
  <attribute name="build" />
  <attribute name="urifile" />
  <attribute name="followLinks" />
  <sequential>
    <antcall target="site">
      <param name="project.home" location="${exporter.home}" />
      <param name="project.start-uri" location="@{uri}" />
      <param name="project.build-dir" location="@{build}" />
      <param name="project.urifile" location="@{urifile}" />
      <param name="project.followLinks" value="@{followLinks}" />
    </antcall>
  </sequential>
</macrodef>
```





forrest

- The aim of the dispatcher concept is to provide a flexible framework for creating site specific layout in different formats.
 - hook's are containers that are used for layout reasons.
 - contract's are functionality or extra content that a theme can use to display the request.

forrest

- structurer to design the pages

```
<forrest:structure type="html" hooksXpath="/html/body">
  <!-- ... -->
  <forrest:hook id="barra_lateral_izq">
    <forrest:contract name="nav-boja-servicios"/>
    <jx:if test="${!isCalendar}">
      <forrest:contract name="content-pdf-link"
        dataURI="cocoon://${niveles[0]}/${niveles[1]}/${niveles[2]}/hasPdf.xml">
        <forrest:property name="number" value="${niveles[2]}"/>
        <forrest:property name="year" value="${niveles[1]}"/>
      </forrest:contract>
    </jx:if>
  </forrest:hook>
  <!-- ... -->
</forrest:structure>
```



forrest

- Forrest solr plugin generates solr documents from xdos.
 - When run with the dispatcher allows you to update solr with the content of your site while generating it (solr-add contract).
 - In dynamic mode it provides a GUI to manage your project in solr (solr-actionbar contract) and a search interface (solr-search contract) to search your solr server.

solr

Solr is an open source enterprise search server based on the Lucene Java search library, with XML/HTTP and JSON APIs, hit highlighting, faceted search, caching, replication, a web administration interface and many more features.



Buscador del BOJA

Buscar en BOJA 

* Introduzca el término de búsqueda Sólo en sumarios
* Este campo es obligatorio

Fecha (Por ejemplo 25/07/2007)

Desde:  Hasta: 

Rango:

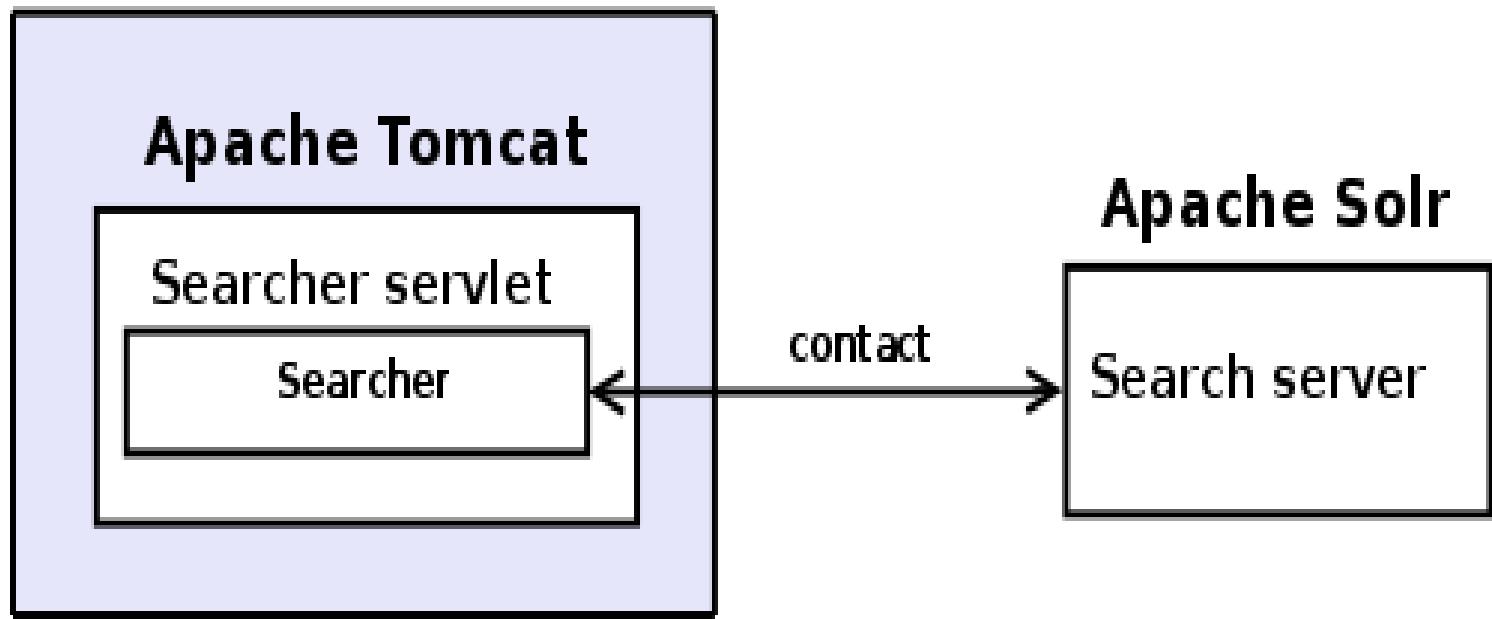
Sección:

Organismo:

BUSCAR



FRONTAL



Buscador del BOJA

 Sólo en Sumarios**BUSCAR**

143957 recursos disponibles.

[Decreto 1/1979, de 30 de Julio de 1979, sobre creación y publicación del Boletín Oficial de la Junta de Andalucía.](#)

Organismo: Presidencia. (Boletín número 1 de 11/08/1979 Sección: Disposiciones generales)

[Decreto 112/1982, de 29 de septiembre, por el que se nombra Inspector General de los Servicios de la Junta de Andalucía a don Manuel Martínez James.](#)

Organismo: Presidencia. (Boletín número 28 de 01/11/1982 Sección: Disposiciones generales)

[CANDIDATURAS presentadas para las elecciones al Parlamento de Andalucía, convocadas por Decreto del Presidente de la Junta de Andalucía 1/2004, de 19 de enero.](#)

Organismo: Otros. JUNTA ELECTORAL DE ANDALUCIA. (Boletín número 28 de 11/02/2004 Sección: Disposiciones generales)

[CANDIDATURAS proclamadas para las elecciones al Parlamento de Andalucía, convocadas por Decreto del Presidente de la Junta de Andalucía 1/2004, de 19 de enero.](#)

Organismo: Otros. JUNTA ELECTORAL DE ANDALUCIA. (Boletín número 32 de 17/02/2004 Sección: Disposiciones generales)





use case

- statistic 2008-08
 - searches: 10.000/daily
 - site index: 1.7 GB
 - numDocs : 314.348

droids

Droids is an intelligent standalone robot framework that allows to create and extend existing droids (robots).

A droid can automatically seek out relevant online information based on the user's specifications and invoke custom handler on this information.



droids

- bulk import of sources
 - crawl external site importing year ranges of official gazettes
- bulk task execution on repository (~500.000 dispositions)
 - update solr with mass content changes
 - change file properties (e.g. date format)
 - create fascicles descriptor
 - generate bulk html updates

httpd

The Apache HTTP Server Project is an effort to develop and maintain an open-source HTTP server for modern operating systems including UNIX and Windows NT. The goal of this project is to provide a secure, efficient and extensible server that provides HTTP services in sync with the current HTTP standards.

ApacheCon



Leading the Wave
of Open Source

The screenshot shows a website for the Boletín Oficial de la Junta de Andalucía (BOJA). At the top, there's a navigation bar with 'PORTADA', 'TEMAS', and 'LA JUNTA'. Below it, a breadcrumb trail says 'Estás en: Portada > Servicios > BOJA > 2008 >'. The main content area is titled 'BOJA' and contains a sidebar with links: 'Último boletín', 'Boletines por fecha', 'Buscador del BOJA', 'Preguntas frecuentes', and 'Otros boletines'. A note below states: 'Atención: La información contenida en estas páginas no es necesariamente exhaustiva, completa, exacta o actualizada. Únicamente los textos publicados en la edición Impresa del Boletín Oficial de la Junta de Andalucía tienen carácter auténtico y validez oficial.' At the bottom, a blue button says 'Descargar boletín nº 203 completo' with a PDF icon.

httpd

- Making static files semi dynamic
 - Split page in parts (each part served from a different html)

A diagram showing the decomposition of a static page into dynamic components. On the left, a purple box represents the original static page. An arrow points from this box to the right, where three separate components are shown: 'Descargar boletín nº 200 completo' (with a PDF icon), 'Descargar fascículo 1 boletín nº 200' (with a PDF icon), and 'Descargar fascículo 2 boletín nº 200' (with a PDF icon).



Sociedad Andaluza para el Desarrollo de la Sociedad de la Información S.A.U.
CONSEJERÍA DE INNOVACIÓN, CIENCIA Y EMPRESA

httpd ssi with forrest

- contract to inject ssi instruction

```
<forrest:content><forrest:part>
  <!--Set string-->
  <xsl:comment>#set var="map" value="/$REWRITEMAP_RESULT"</xsl:comment>
  <!-- get year/number from map -->
  <xsl:comment>#if expr="$map == /^\\boletines\\(\\d{4})\\(\\d+\\)/" </xsl:comment>
  <xsl:comment>#set var="mapYear" value="$1" </xsl:comment>
  <xsl:comment>#set var="mapNumber" value="$2" </xsl:comment>
  <xsl:comment>#endif </xsl:comment>
  <!-- get year/number from request -->
  <xsl:comment>#if expr="$REQUEST_URI == /^\\boletines\\(\\d{4})\\(\\d+\\)/" </xsl:comment>
  <xsl:comment>#set var="year" value="$1" </xsl:comment>
  <xsl:comment>#set var="number" value="$2" </xsl:comment>
  <xsl:comment>#endif </xsl:comment>
  <!-- ... -->
```



httpd ssi with forrest

- contract to inject ssi instruction

```
<!-- ... -->
<ul>
  <!-- compare both and set the focus -->
  <xsl:comment>#if expr="$year=$mapYear && $number=$mapNumber" </xsl:comment>
  <li><a accesskey="U" class="actual" href="/BOJA">Último boletín</a></li>
  <li><a accesskey="F" href="/boja/boletines/">Boletines por fecha</a></li>
  <xsl:comment>#else</xsl:comment>
  <li><a accesskey="U" href="/BOJA">Último boletín</a></li>
  <li><a accesskey="F" class="actual" href="/boja/boletines/"> Boletines por fecha</a></li>
  <xsl:comment>#endif</xsl:comment> ... </ul> ...
<div id="texto_informativo"><p><strong>Atención:</strong> ...</p></div>
</forrest:part>
</forrest:content>
```

httpd

- Making static files semi dynamic
 - Page created with ssi injection contract mentioned before
 - Activate the rewrite

RewriteMap portadaboja txt:/opt/datos/httpd/redirect.txt

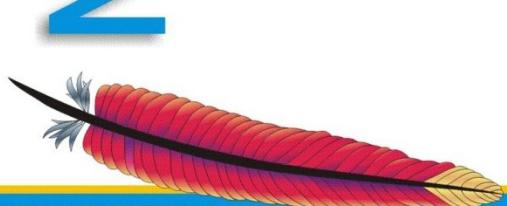
**RewriteRule ^(.*) %{DOCUMENT_ROOT}\$1
[E=REWRITEMAP_RESULT: \${portadaboja:boletin},L]**



next steps

- Using JCR repository to store internal data (Sling/Jackrabbit)
- Replace Tomcat with Felix
- Creating admin interface for solr
- Creating web admin interface for droids

ApacheCon



Leading the Wave
of Open Source



Sociedad Andaluza para el Desarrollo de la Sociedad de la Información S.A.U.
CONSEJERÍA DE INNOVACIÓN, CIENCIA Y EMPRESA



Thank you
for your attention

Thorsten Scherler

Sociedad Andaluza para el Desarrollo
de la Sociedad de la Información S.A.U. (SADESI)

thorsten@apache.org

ApacheCon US 2008, New Orleans, 07 November 2008